

SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA
XXVII CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA

**IMPLEMENTACIÓN PRELIMINAR DE MODELOS MACHINE LEARNING
PARA UN SISTEMA DE PRONÓSTICO DE OLAJE**

RODRIGO CAMPOS-CABA¹
SEBASTIAN CORREA²
LORENZO MENTASCHI³

RESUMEN

La predicción eficiente del oleaje es crucial para garantizar la operatividad portuaria, proteger a las comunidades costeras y fortalecer la preparación ante eventos extremos, especialmente en un contexto de cambio climático. Si bien la Inteligencia Artificial (IA) ha ganado terreno en la predicción de variables meteorológicas y oceanográficas, las comparaciones sistemáticas entre modelos de IA y modelos numéricos de alta resolución siguen siendo escasas, particularmente en el ámbito costero chileno. Este estudio aborda esta brecha mediante la comparación entre un modelo dinámico de referencia (SWAN-UV) y seis modelos de aprendizaje automático (ML), desde enfoques simples como la Regresión Lineal Multivariada hasta arquitecturas más complejas de redes neuronales. Todos los modelos ML fueron entrenados con 4 años de datos observacionales de la boya del Puerto de Tocopilla.

Los resultados mostraron que todos los modelos ML superaron a SWAN-UV en la mayoría de las métricas evaluadas, incluyendo RMSE, MAD y MADc. En particular, destacaron por su capacidad para representar con mayor precisión la distribución y variabilidad temporal de la altura significativa de ola, aspecto clave en la caracterización de eventos extremos como marejadas. Estos hallazgos sugieren que los modelos ML pueden constituir una alternativa eficaz y de bajo costo computacional frente a los modelos dinámicos tradicionales. Así, el aprendizaje automático se posiciona como una herramienta prometedora para el desarrollo de sistemas de alerta y pronóstico de marejadas en Chile.

¹ Investigador asociado, Centro Interdepartamental de Investigación para Ciencias Ambientales, Universidad de Bolonia - email: rodrigo.camposcaba@unibo.it

² Encargado del Sistema de Alerta de Marejadas UV, Escuela de Ingeniería Civil Oceánica, Universidad de Valparaíso – email: sebastian.correa@uv.cl

³ Profesor titular, Centro Interdepartamental de Investigación para Ciencias Ambientales, Universidad de Bolonia - email: lorenzo.mentaschi@unibo.it

1. INTRODUCCION

La predicción precisa de la altura significativa de oleaje es fundamental para una amplia gama de aplicaciones en ingeniería costera, gestión de riesgos, operación de puertos y planificación de actividades marítimas (Tsai et al., 2002). En particular, las costas de Chile, con su extensa línea costera expuesta al océano Pacífico y una dinámica oceanográfica compleja, presentan un escenario desafiante y estratégico para el desarrollo de modelos de predicción robustos y eficientes.

Tradicionalmente, la estimación del oleaje se ha basado en modelos numéricos (dinámicos) como WaveWatch III (The WAVEWATCH III Development Group, 2019) o SWAN (Ris et al., 1994), que requieren condiciones de contorno atmosféricas y oceánicas, además de una significativa capacidad computacional (Jörges et al., 2021). Si bien estos modelos han demostrado un desempeño aceptable, su resolución espacial y temporal, junto con el costo computacional, limitan su aplicabilidad operativa en zonas costeras específicas o para largas escalas temporales (Zhang et al., 2024).

En este contexto, los enfoques basados en Inteligencia Artificial (IA) y aprendizaje automático (Machine Learning, ML) han emergido como herramientas prometedoras para complementar los métodos tradicionales. Estos modelos, una vez entrenados con datos históricos, pueden ofrecer predicciones rápidas y adaptadas a ubicaciones específicas, manteniendo una buena precisión incluso en fenómenos no lineales (Zhang et al., 2024).

A nivel global, diversos estudios han explorado distintas técnicas para mejorar la predicción de la altura significativa del oleaje. Entre los modelos más utilizados se encuentran la Regresión Lineal Multivariada (Elbisy & Elbisy, 2021), el Perceptrón Multicapa (Altunkaynak, 2013; James et al., 2018; Elbisy & Elbisy, 2021), las Redes Neuronales Recurrentes y las Redes de Memoria a Corto y Largo Plazo (Jörges et al., 2021; Gao et al., 2021; Chen et al., 2022; Zhang et al., 2024).

En Sudamérica, han comenzado a surgir aplicaciones regionales del ML para oleaje. Minuzzi & Farina (2022) estudiaron siete ubicaciones en la costa brasileña usando Redes de Memoria a Corto y Largo Plazo, demostrando que los modelos de redes recurrentes pueden funcionar como sustitutos computacionalmente eficientes de los modelos numéricos, con un desempeño cercano a 87% comparado con observaciones. Sin embargo, en la región la aplicación de este tipo de técnicas sigue siendo poco explorada.

En Chile, la investigación sobre el uso de modelos de aprendizaje automático en oleaje ha sido incipiente, pero con resultados prometedores. Matamala (2012) aplicó redes neuronales artificiales para transferir parámetros desde boyas profundas (TRIAXYS) hacia aguas someras, demostrando que, incluso con series de solo cinco años, era posible obtener buenos ajustes. Posteriormente, el Instituto Nacional de Hidráulica (INH, 2021) implementó algoritmos de ML, específicamente redes neuronales y XGBoost, para corregir las salidas del modelo numérico SWAN. Mediante la predicción del error entre el modelo y las mediciones de un ADCP, se logró una mejora significativa en la estimación de la altura significativa de oleaje. Ambos enfoques alcanzaron coeficientes de determinación superiores a 0.76 y errores cuadráticos medios inferiores a 0.3 m, lo que evidencia el potencial del ML para perfeccionar

la modelación numérica en zonas con alta variabilidad espacial y complejidades batimétricas. Más recientemente, Puerto Mejillones ha desarrollado una nueva plataforma de predicción operativa, que permite anticipar con alta precisión los cierres del terminal por marejadas, integrando inteligencia artificial, datos históricos propios y variables oceanográficas del entorno local⁴.

Con el objetivo de contribuir a la exploración de modelos de inteligencia artificial aplicados a variables oceanográficas en Chile, este trabajo analiza el uso de estas herramientas para el downscaling de la altura significativa del oleaje, específicamente en el Puerto de Tocopilla. Es importante destacar que, en este estudio, los modelos de IA implementados se denominan específicamente como “modelos de aprendizaje automático” (modelos ML), ya que han sido aplicados en el contexto de regresión de series de tiempo.

El resto del documento se organiza de la siguiente forma. La Sección 2 describe los materiales y métodos empleados, incluyendo los datos utilizados para el entrenamiento de los modelos ML, sus definiciones, configuraciones y parametrizaciones. En la Sección 3 se exponen los principales resultados obtenidos, comparando el desempeño de los modelos ML con un modelo dinámico de alta resolución. La Sección 4 plantea una discusión del trabajo realizado. Finalmente, la Sección 5 expone las principales conclusiones con base en los resultados obtenidos.

2. MATERIALES Y METODOS

En las siguientes secciones se describen los datos utilizados y los métodos aplicados para el desarrollo de este estudio. La Sección 2.1 describe el modelo dinámico de alta resolución utilizado como referencia para los modelos ML. Las Secciones 2.2 describen los datos utilizados como variable objetivo (variable dependiente) y predictores (variables independientes), respectivamente. La configuración de los modelos de aprendizaje automático y los métodos empleados durante los procesos de entrenamiento y evaluación se describen en las Secciones 2.3 y 2.4 respectivamente.

2.1 MODELO DINAMICO DE ALTA RESOLUCION

El modelo de alta resolución utilizado para la comparación con los modelos ML se generó mediante simulaciones numéricas basadas en downscaling dinámico (SWAN-UV), utilizando el modelo espectral de oleaje SWAN (Ris et al., 1994) en modo no estacionario. Se configuró el dominio espectral con una discretización direccional de 2°, abarcando de 180° a 360°, y una discretización frecuencial logarítmica con una frecuencia mínima de 0.0345 Hz y máxima de 0.4975 Hz. La batimetría se obtuvo a partir de cartas náuticas electrónicas y datos de campañas batimétricas con ecosonda multihaz, proporcionados por el Puerto de Tocopilla (Figura 1a).

⁴ Portal Portuario. Disponible en: [<https://portalportuario.cl/puerto-mejillones-implementa-plataforma-de-prediccion-portuaria-basada-en-inteligencia-artificial/>].

La malla numérica fue generada con la herramienta OceanMesh2D (Roberts et al., 2019), abarcando espacialmente desde los 20.9°S (norte) hasta los 23.25°S (sur) de latitud, y desde los 72°W (oeste) hasta los 70°W (este) de longitud, con elementos de tamaño variable entre 10 km y 25 m (Figura 1b). La condición de borde espectral fue forzada con los espectros de aguas profundas obtenidos de la actualización de la base de datos de oleaje para Chile desarrollada por Correa et al. (2025), calibrada y validada con datos de boyas y altimetría satelital. Las salidas espectrales del modelo SWAN-UV fueron extraídas en la misma ubicación donde se encuentra la boya medidora de oleaje.

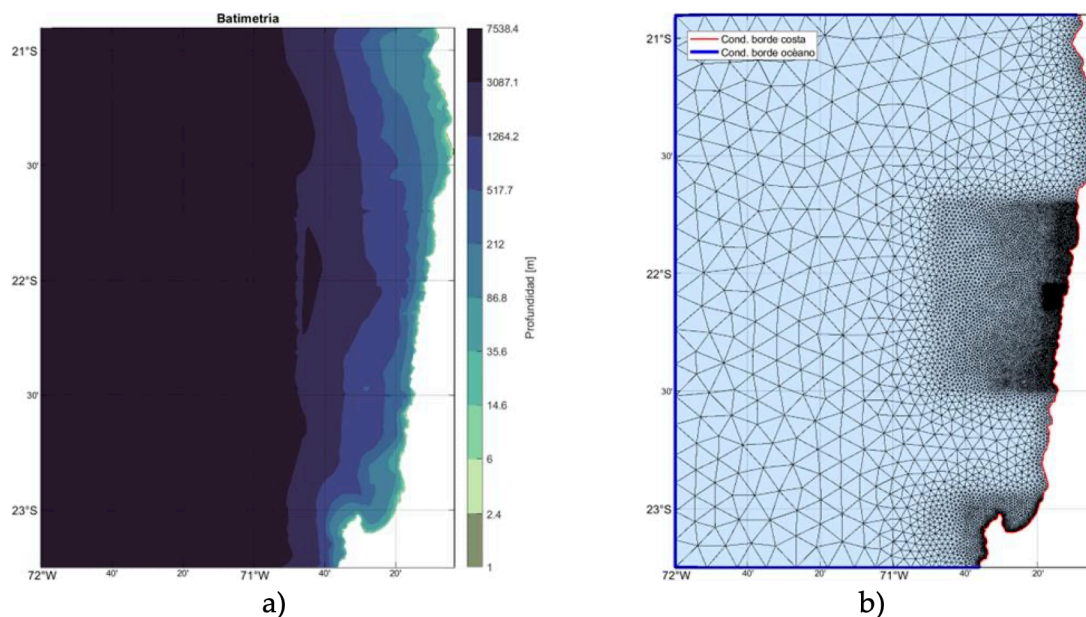


Figura 1: a) Batimetría modelo local. b) Dominio numérico

2.2 VARIABLE OBJETIVO Y PREDICTORES

En este estudio la variable objetivo corresponde a la altura significativa de oleaje (H_s) proveniente de mediciones de boya Spotter en Puerto Tocopilla, proporcionados por la empresa SQM. Los datos cubren una extensión temporal entre septiembre 2020 hasta mayo 2025, en la ubicación latitud -22.09° y longitud -70.21° .

Los predictores incluidos para la implementación de los modelos ML son variables meteorológicas y oceanográficas que influyen en la predicción de la altura de oleaje y se han utilizado en trabajos similares recientes (e.g., Minuzzi & Farina, 2022; Gao et al., 2021; Zhang et al., 2024). En concreto, los predictores considerados corresponden a la altura significativa de las olas y a los vientos zonales y meridionales, todos de ERA5 (Hersbach et al., 2020).

aguas afuera?

El dominio espacial utilizado para los predictores se determinó mediante múltiples ejecuciones y análisis de desempeño de Regresión Lineal Multivariada. La Figura 2 ilustra el dominio seleccionado mostrando los nodos de los predictores, junto con la ubicación de la variable objetivo.




Figura 2: Dominio considerado para los predictores (Nodos ERA5) y ubicación de variable objetivo (Boya Tocopilla).

*suavero expandir
respecto de la
necesidad de
este paso.
Esto reduce la
varianza
y por
tanto,
podría
limitar
errores
extremos*

Dado que la mayoría de los predictores considerados son campos de parámetros en el tiempo (latitud, longitud, tiempo) y el problema a resolver es una regresión de series de tiempo, se aplica un paso de reducción de dimensionalidad para reducir la variabilidad espacial mediante el Análisis de Componentes Principales (PCA, por su sigla en inglés). Para esta tarea, se utilizó la función "pca" disponible en MATLAB.

La construcción de los predictores utilizados para la implementación de los modelos ML considera los tres primeros componentes principales (PC) de la altura significativa de ola y los siete primeros PC de las componentes del viento, los cuales se incluyen por separado, es decir, sin reconstruir una única serie temporal del predictor. La cantidad de PC empleada fue seleccionada mediante la ejecución de modelos de Regresión Lineal Multivariada con distintos números de componentes principales y la posterior evaluación del rendimiento de los modelos, buscando un equilibrio entre desempeño y complejidad que se logró con la cantidad mencionada de PC por cada predictor.

2.3 CONFIGURACION DE LOS MODELOS ML

Los modelos de aprendizaje automático se implementaron en Python utilizando la biblioteca PyTorch (Paszke et al., 2017), y fueron diseñados específicamente para tareas de predicción de series de tiempo. Se evaluaron seis configuraciones distintas, desde enfoques lineales hasta arquitecturas de redes neuronales profundas:

- Regresión Lineal Multivariada (MLR): Modelo lineal clásico que estima los coeficientes mediante mínimos cuadrados, capturando relaciones lineales entre predictores y variable objetivo.

- Perceptrón Multicapa (MLP): Red neuronal feedforward totalmente conectada con dos capas ocultas de 120 neuronas y activaciones ReLU, adecuada para modelar relaciones no lineales en series temporales.
- Red Neuronal Recurrente Simple (RNNs): Arquitectura con una única capa recurrente de 120 unidades, capaz de capturar dependencias temporales mediante la retroalimentación de sus estados ocultos (memoria interna).
- Red Neuronal Recurrente Híbrida (RNNh): Combina una capa RNN (60 unidades) con una capa lineal que transforma directamente las entradas. Ambas salidas se concatenan tras aplicar una activación ReLU, lo que mejora la expresividad del modelo y permite el reconocimiento de patrones no-lineales.
- Red LSTM Simple (LSTMs): Modelo con una capa LSTM de 120 unidades, adecuado para secuencias con dependencias de largo plazo, gracias a su mecanismo de compuertas internas.
- Red LSTM Híbrida (LSTMh): Integra una capa LSTM (60 unidades) y una capa lineal con activación ReLU, cuyas salidas se concatenan para combinar el aprendizaje secuencial con transformaciones adicionales de las características de entrada.

La arquitectura y el número de unidades ocultas de los modelos no lineales (MLP, RNN y LSTM) fueron seleccionados tras pruebas exploratorias que buscaron el mejor desempeño predictivo para cada configuración.

2.4 ENTRENAMIENTO, VALIDACION Y EVALUACION

Para el entrenamiento y evaluación de los modelos ML, los predictores fueron estandarizados, asegurando que todas las variables tuvieran un peso comparable y evitando que aquellas con mayor magnitud dominaran el aprendizaje.

El conjunto de datos se dividió en tres períodos: entrenamiento (2020–2023), validación (2024) y prueba (2025). Cada modelo fue entrenado 10 veces, utilizando 2.000 epochs por ejecución, excepto el modelo MLR, que fue entrenado durante 10.000 epochs. Se utilizó el error cuadrático medio (MSE) como función de pérdida y el optimizador Adam para el ajuste de los parámetros.

La selección del mejor modelo se basó en el desempeño sobre el conjunto de validación, siguiendo un enfoque comúnmente adoptado para evitar sobreajuste (Bishop, 2014; Heaton, 2018). Para garantizar un rendimiento robusto, también ante eventos extremos, se evaluaron diferentes métricas de desempeño durante el periodo de validación. Entre estas métricas, la pendiente del ajuste lineal entre las predicciones y las observaciones se destacó como el criterio más efectivo para seleccionar la ejecución final, al reflejar la capacidad del modelo para capturar la intensidad de los eventos extremos.

Una vez seleccionada la mejor ejecución, el desempeño final se evaluó sobre el conjunto de prueba, utilizando datos horarios y comparando tanto con observaciones como con las simulaciones del modelo SWAN como referencia. Las métricas de evaluación incluyeron: la pendiente del ajuste lineal (SLF), el coeficiente de correlación de Pearson (Corr), el error cuadrático medio (RMSE), y la desviación media absoluta (MAD). Además, se aplicaron métricas ~~personales~~ propuestas por Campos-Caba et al. (2024): la MAD de percentiles (MADp), que evalúa la representación de la distribución acumulada, y el MAD corregido (MADc = MAD + MADp), que combina errores temporales y estadísticos. Estas métricas permiten valorar tanto la precisión temporal como la fidelidad estadística del modelo.

donde está el tiempo en esto?
son todos estadísticos.

3. RESULTADOS

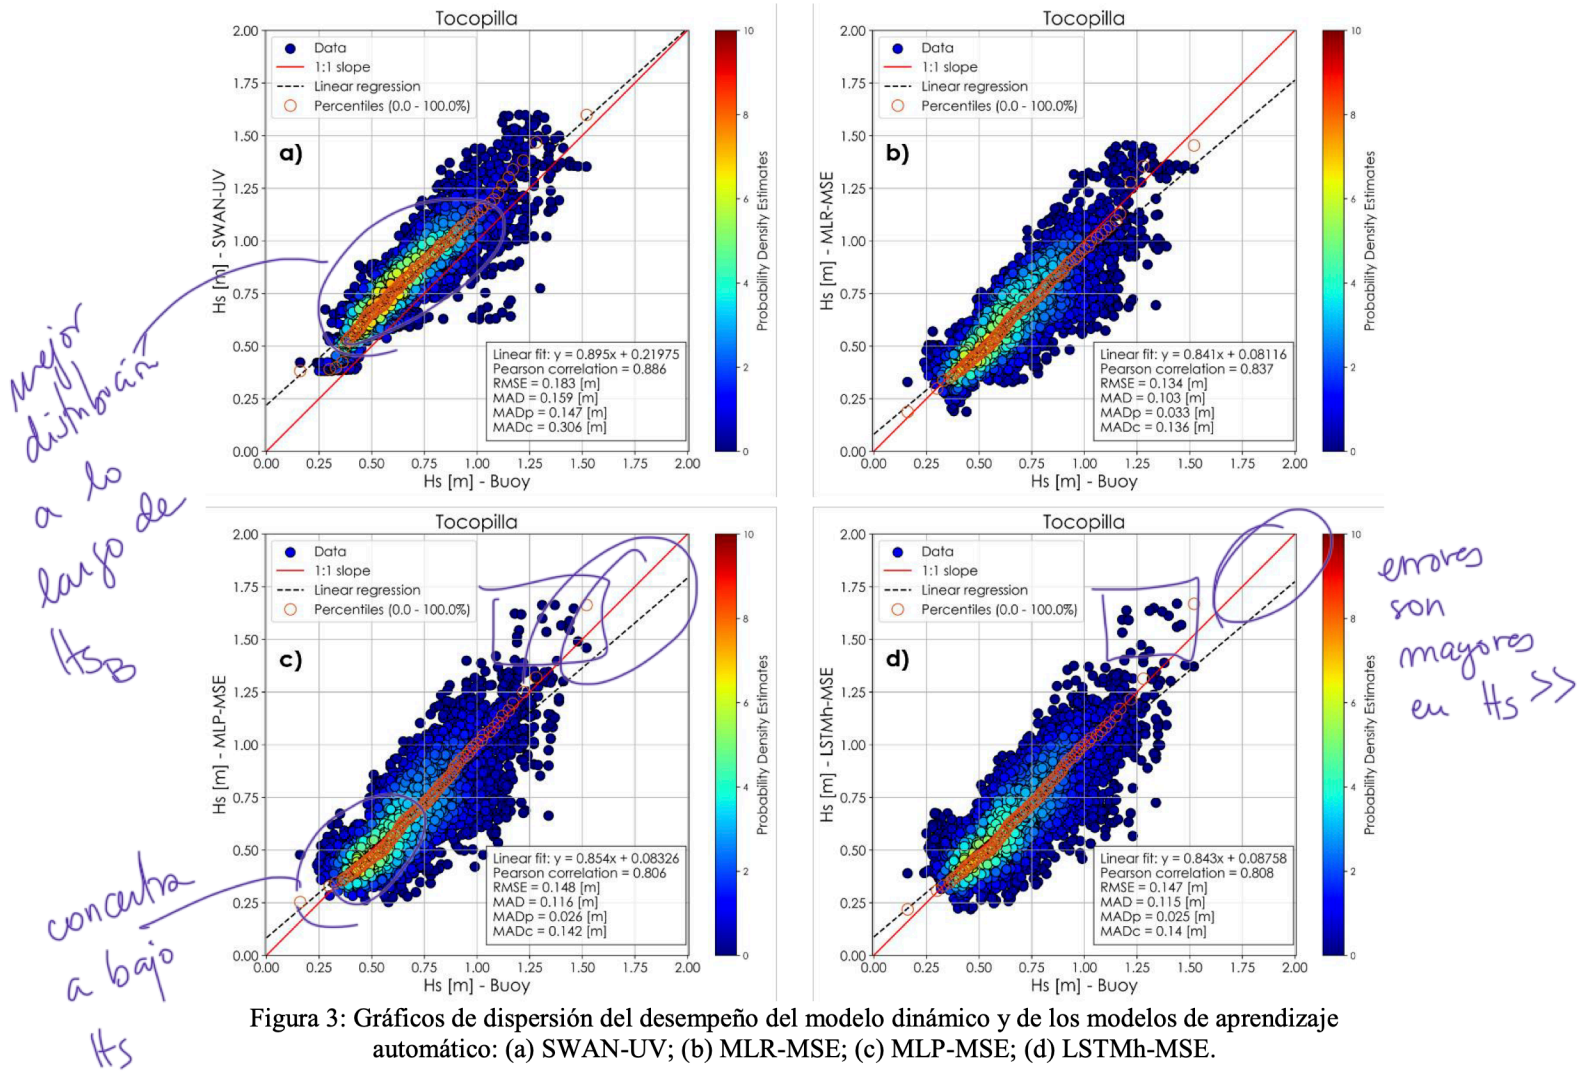
La Tabla 1 presenta los principales indicadores de desempeño del modelo dinámico de referencia SWAN-UV y de los seis modelos ML implementados, todos entrenados utilizando el MSE como función objetivo. Entre todos los modelos, el MLR-MSE obtuvo el menor RMSE (0.134 m), así como los valores más bajos de MAD (0.103 m) y MADc (0.136 m), superando de forma notable a SWAN-UV a pesar de su simplicidad. Los modelos basados en redes neuronales (MLP, RNNs, RNNh, LSTMs y LSTMh) también presentaron un mejor desempeño que SWAN-UV en la mayoría de los indicadores de error, destacando especialmente métricas tradicionales como RMSE y en MADp, en esta última donde todos los modelos ML alcanzaron valores considerablemente menores (≤ 0.033 m) frente a los 0.147 m del modelo dinámico, lo que evidencia una mayor capacidad para representar la distribución de la variable objetivo.

Tabla 1: Resumen comparativo de métricas de desempeño del modelo SWAN-UV y modelos ML. Se resalta en negrita el mejor resultado por métrica.

		Métricas					
		SLF	Corr	RMSE m	MAD m	MADp m	MADc m
	SWAN-UV	0.895	0.886	0.183	0.159	0.147	0.306
Modelos ML	MLR-MSE	0.841	0.837	0.134	0.103	0.033	0.136
	MLP-MSE	0.854	0.806	0.148	0.116	0.026	0.142
	RNNs-MSE	0.838	0.806	0.148	0.115	0.026	0.141
	RNNh-MSE	0.867	0.813	0.146	0.115	0.024	0.139
	LSTMs-MSE	0.833	0.797	0.150	0.118	0.023	0.141
	LSTMh-MSE	0.843	0.808	0.147	0.115	0.025	0.140

La Figura 3 muestra gráficos de dispersión correspondientes al modelo dinámico de referencia SWAN-UV y a los modelos de aprendizaje automático MLR-MSE (el modelo ML más simple), MLP-MSE (el modelo de red neuronal más simple) y LSTMh-MSE (el modelo ML más sofisticado). A pesar de que SWAN-UV (Figura 3a) presenta los valores más altos

de SLF (0.895) y correlación de Pearson (0.886), se observa que, en general, las alturas de ola están sobreestimadas, lo que provoca una sobreestimación de los percentiles y refleja una menor capacidad para representar adecuadamente la distribución de la variable objetivo. Por otra parte, los modelos ML muestran una clara mejora en la representación de los percentiles, incluso en el caso del simple MLR-MSE, aunque los modelos MLP-MSE y LSTMh-MSE tienden a subestimar los valores más altos de altura de ola.



La Figura 4 presenta las series de tiempo correspondientes al período de prueba, incluyendo la variable objetivo (boya), el modelo dinámico SWAN-UV y los modelos de aprendizaje automático MLR-MSE, MLP-MSE y LSTMh-MSE. Se observa que la serie generada por el modelo SWAN-UV exhibe una señal suavizada, con valores generalmente superiores a las alturas de ola observadas, comportamiento que coincide con lo descrito previamente en la Figura 3. En contraste, los modelos ML tienden a reproducir con mayor fidelidad la variabilidad presente en la señal observacional, caracterizada por una mayor irregularidad.

Respecto a la representación del evento más extremo registrado durante el período de prueba, se aprecia en la Figura 4b que los modelos SWAN-UV y MLR-MSE subestiman el pico y MLP-MSE y LSTMh-MSE tienden a sobreestimarlos. En general los modelos ML demuestran su capacidad para representar la evolución de este tipo de episodios.

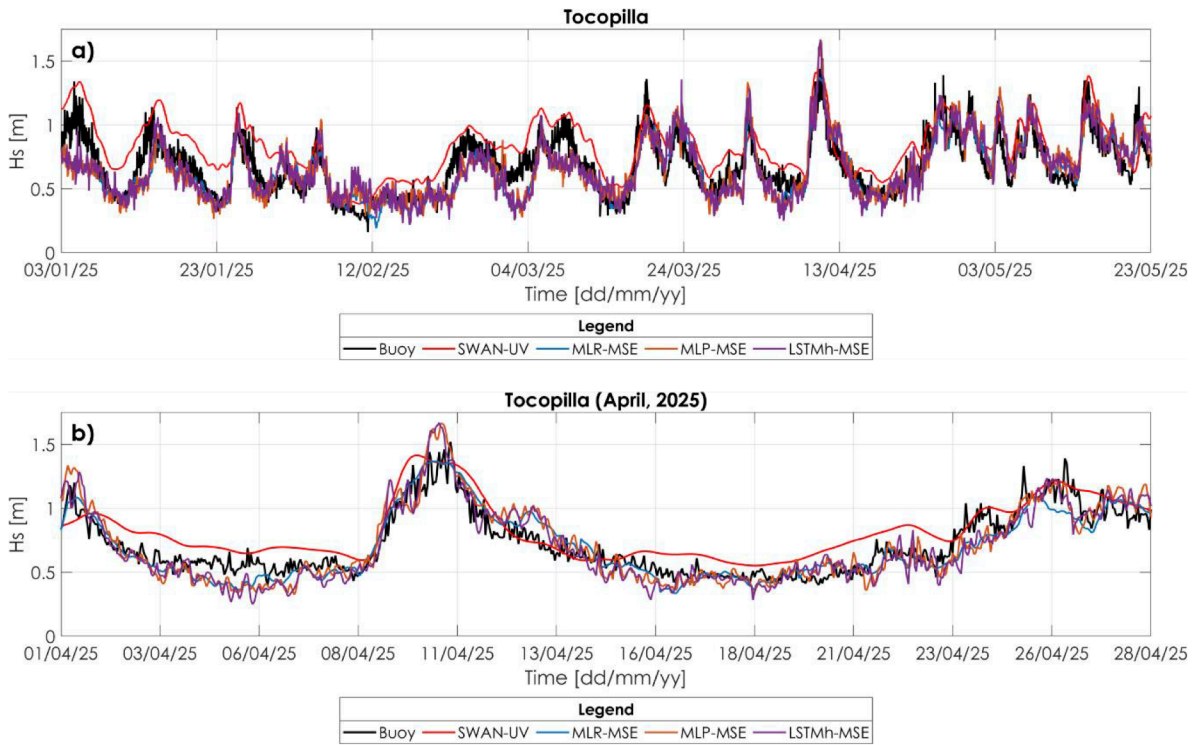


Figura 4 Series de tiempo de la variable objetivo (buoy), modelo dinámico SWAN-UV y los modelos ML MLR-MSE, MLP-MSE y LSTMh-MSE. (a) Período de testeo completo; (b) Abril, 2025.

4. DISCUSION

debatible

La metodología seguida ha demostrado una implementación exitosa de los modelos de ML considerados. No obstante, su desempeño podría verse limitado por el uso de PCA para reducir la dimensionalidad espacial de los predictores. Si bien esta técnica permite conservar aquellos componentes que explican la mayor parte de la varianza del conjunto de datos, su aplicación implica una transformación lineal de las variables originales. Esta linealización puede pasar por alto patrones o interacciones no lineales relevantes presentes en los predictores, los cuales pueden ser clave para representar adecuadamente la dinámica compleja de las marejadas.

Como alternativa, es posible implementar capas de codificación, las que permiten aprender y extraer relaciones no lineales directamente desde los predictores, proporcionando una representación más flexible y ajustada a los datos. Al incorporar estas capas, los modelos podrían mejorar su capacidad para capturar dependencias sutiles tanto en el espacio como en el tiempo, lo que eventualmente redundaría en un mejor desempeño predictivo.

El entrenamiento de los modelos utilizando datos observacionales refuerza su capacidad para aprender directamente de las propiedades físicas y estadísticas de las observaciones, permitiendo capturar dinámicas más sutiles y reducir los sesgos sistemáticos que podrían generarse al entrenar con salidas de un modelo dinámico. Sin embargo, los datos observacionales suelen estar limitados por su cobertura espacial y temporal, o por incertidumbres de medición, lo que puede influir negativamente en el proceso de entrenamiento. Además, el éxito de esta estrategia depende de la disponibilidad de datos observacionales de alta calidad, una condición que no siempre se cumple en muchas regiones o para ciertos fenómenos de interés.

En cuanto a la eficiencia de los modelos, tanto el downscaling dinámico como el entrenamiento de los modelos ML se realizaron en infraestructuras computacionales personales de alto rendimiento. El modelo dinámico SWAN-UV fue ejecutado en un computador de escritorio, completando cinco años de simulaciones en aproximadamente 15 h, sin incluir el tiempo adicional requerido para generar espectros bidireccionales de aguas profundas. En contraste, los modelos ML fueron entrenados en un computador portátil con GPU dedicada, logrando una reducción significativa en los tiempos de cómputo. Las ejecuciones completas (entrenamiento + validación) oscilaron entre 10 s (modelo MLP) y 80 s (modelo LSTM), lo que representa una eficiencia computacional considerable en comparación con el enfoque dinámico.

5. CONCLUSIONES

La exploración de modelos ML ha revelado su potencial como alternativas eficientes al downscaling dinámico. Modelos relativamente simples, como MLR y MLP, han demostrado ofrecer un rendimiento confiable con un costo computacional considerablemente menor.

El entrenamiento directo con datos observacionales, particularmente en la localidad de Tocopilla, evidenció la solidez de los modelos ML, los cuales lograron superar al modelo dinámico SWAN-UV en métricas clave como RMSE, MAD y MADc. Además, destacaron por su mejor representación de los percentiles de las alturas de ola, lo que se traduce en una caracterización más precisa de la distribución de la variable objetivo.

Estos resultados confirman que los modelos ML, al ser entrenados con datos observacionales de calidad, son capaces de representar adecuadamente la evolución temporal de la altura significativa de ola, incluyendo eventos extremos. Esto subraya la importancia de contar con series de datos confiables y de alta resolución, y demuestra que los modelos ML pueden captar patrones temporales relevantes de forma más eficiente que algunos enfoques dinámicos, al menos en ciertos contextos.

En conjunto, los hallazgos de este estudio posicionan al aprendizaje automático como una herramienta competitiva y versátil para la predicción del oleaje en Chile, con particular utilidad en el pronóstico de condiciones extremas asociadas a marejadas. Dado el alto costo computacional y la complejidad operativa de los modelos dinámicos, los modelos ML emergen como una alternativa transformadora. Su capacidad para entregar resultados robustos con una infraestructura modesta (bastando una estación de trabajo con una GPU

adecuada) refuerza su potencial para complementar o incluso reemplazar, a largo plazo, los métodos numéricos tradicionales. A medida que la calidad de los datos continúa mejorando y las técnicas de ML evolucionan, es probable que estos enfoques redefinan el panorama de la ingeniería costera y la predicción de oleaje, ofreciendo soluciones más rápidas, accesibles y precisas.

AGRADECIMIENTOS

Los autores agradecen a Joaquín Barra Coñolef, Jefe Operaciones Marítimas y Terrestres, Puerto SQM Tocopilla, quien ha brindado acceso a los datos observacionales utilizados como variable objetivo en este estudio.

REFERENCIAS

Altunkaynak, A. (2013). Prediction of significant wave height using geno-multilayer perceptron. *Ocean Engineering*, 58, 144–153. <https://doi.org/10.1016/j.oceaneng.2012.08.005>

Bishop, C. M. (2014). Bishop - Pattern Recognition and Machine Learning - Springer 2006. *Antimicrobial Agents and Chemotherapy*, 58(12).

Campos-Caba, R., Alessandri, J., Camus, P., Mazzino, A., Ferrari, F., Federico, I., Vousdoukas, M., Tondello, M., & Mentaschi, M. (2024). Assessing the storm surge model performance: what error indicators can measure the skill? *Ocean Sci.*, 20. <https://doi.org/10.5194/os-20-1513-2024>

Chen, J., Ashton, I. G. C., Steele, E. C. C., & Pillai, A. C. (2022). A Real-Time Spatiotemporal Machine Learning Framework for the Prediction of Nearshore Wave Conditions. *Artificial Intelligence for the Earth Systems*, 2(1). <https://doi.org/10.1175/aies-d-22-0033.1>

Correa, S., Aguirre, C., Becerra, D., Molina, M., Vilchez, P., & Bahamóndez, S. (2025). Upgrade of the Chilean Wave Atlas database. *Ocean Modelling*, 193, 102456. <https://doi.org/10.1016/j.ocemod.2024.102456>

Elbisy, M. S., & Elbisy, A. M. S. (2021). Prediction of significant wave height by artificial neural networks and multiple additive regression trees. *Ocean Engineering*, 230. <https://doi.org/10.1016/j.oceaneng.2021.109077>

Gao, S., Huang, J., Li, Y., Liu, G., Bi, F., & Bai, Z. (2021). A forecasting model for wave heights based on a long short-term memory neural network. *Acta Oceanologica Sinica*, 40(1), 62–69. <https://doi.org/10.1007/s13131-020-1680-3>

Heaton, J. (2018). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning: The MIT Press, 2016, 800 pp, ISBN: 0262035618 Article. *Genetic Programming and Evolvable Machines*, 19(1–2).

Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., ... Thépaut, J. N. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730). <https://doi.org/10.1002/qj.3803>

Instituto Nacional de Hidráulica. (2021). *Sistema de predicción de oleaje*.

James, S. C., Zhang, Y., & O'Donncha, F. (2018). A machine learning framework to forecast wave conditions. *Coastal Engineering*, 137. <https://doi.org/10.1016/j.coastaleng.2018.03.004>

Jörges, C., Berkenbrink, C., & Stumpe, B. (2021). Prediction and reconstruction of ocean wave heights based on bathymetric data using LSTM neural networks. *Ocean Engineering*, 232. <https://doi.org/10.1016/j.oceaneng.2021.109046>

Matamala, M. (2012). *Redes neuronales artificiales aplicadas a la predicción y estimación de los parámetros del oleaje*.

Minuzzi, F. C., & Farina, L. (2022). A deep learning approach to predict significant wave height using long short-term memory. *Ocean Modelling*. <https://doi.org/10.1016/j.ocemod.2022.102151>

Paszke, A., Gross, S., Chintala, S., Chanan, G., Yang, E., Facebook, Z. D., Research, A. I., Lin, Z., Desmaison, A., Antiga, L., Srl, O., & Lerer, A. (2017). *Automatic differentiation in PyTorch*.

Ris, R. C., Booij, N., & Holthuijsen, L. H. (1994). *Spectral wave model for the coastal zone*.

Roberts, K. J., Pringle, W. J., & Westerink, J. J. (2019). OceanMesh2D 1.0: MATLAB-based software for two-dimensional unstructured mesh generation in coastal ocean modeling. *Geoscientific Model Development*, 12(5). <https://doi.org/10.5194/gmd-12-1847-2019>

The WAVEWATCH III Development Group. (2019). User manual and system documentation of WAVEWATCH III version 6.07. *Tech. Note 333, NOAA / NWS / NCEP / MMAB, Colleague Park, MD, USA, 465 Pp.*, 333.

Tsai, C.-P., Lin, C., & Shen, J.-N. (2002). Neural network for wave forecasting among multi-stations. In *Ocean Engineering* (Vol. 29). www.elsevier.com/locate/oceaneng

Zhang, J., Luo, F., Quan, X., Wang, Y., Shi, J., Shen, C., & Zhang, C. (2024). Improving wave height prediction accuracy with deep learning. In *Ocean Modelling* (Vol. 188). Elsevier Ltd. <https://doi.org/10.1016/j.ocemod.2023.102312>